Abdalan Andrade do Nascimento
Girlene Cordeiro de Lima Santos

Pegada hídrica da inteligência artificial moderna: além da sede tecnológica

Gease ~ 2025

Abdalan Andrade do Nascimento
Girlene Cordeiro de Lima Santos

Pegada hídrica da inteligência artificial moderna: além da sede tecnológica

Gease ~ 2025

CONSELHO EDITORIAL

Patrício Borges Maracajá - UFCG
Tatiana Cristina Vasconcelos - UEPB
Ennio Artur Aires Porto Ferreira - UNIFIP
Aline Carla de Medeiros - UFCG
José Ozildo dos Santos - UFCG
Aline Carla de Medeiros - UFCG
José Givaldo de Sousa - UNIP/UNIFIP
Danielly Carneiro de Azevedo - UFCG
Fernando Kidelmar Dantas de Oliveira - UFCG
Jakson Luís Galdino Dourado - UNIFIP
Alecksandra Vieira de Lacerda - UFCG
Silvia Regina Gobbo Rodrigues - UnB
Juliana Roriz Aarestrup - IFMT
Marisa Artmann – IFMT
Ênnyo José Barros de Araújo - FRCG
Samara Campos de Assis - UNIFIP
Rosângela Vieira Freire – IFCE
Eriana Serpa Barreto - UFMT

FICHA CATALOGRÁFICA

Nascimento, Abdalan Andrade do; Santos, Girlene Cordeiro de Lima. **Pegada hídrica da inteligência artificial moderna**: além da sede tecnológica. Campina Grande-PB: GEASE, 2025**.**

54 p.
Livro digital
ISBN 978-65-01-88366-3

1. Pegada hídrica. 2. Inteligência artificial moderna.
3. Sede tecnológica. I. Título. II. Autores.

Pegada hídrica da inteligência artificial moderna: além da sede tecnológica

Nadie puede pensar en que se puede tener calidad de vida y un desarrollo personal adecuado en un entorno natural degradado. Con un aire irrespirable, con ríos pestilentes, con nuestros campos y montañas arrasados y la fauna desaparecida ¿Quién puede ser feliz? ¿Qué podemos enseñar a nuestros hijos?

Gabriel Ferrer

Sumário

Introdução..... 11

Referencial teórico..... 15

Metodologia..... 23

Resultados..... 27

Pegada hídrica operacional e a sede visível dos *Data Centers*..... 27

Consumo hídrico energético indireto..... 29

Consumo hídrico na cadeia de suprimentos..... 31

Conclusão..... 43

Referências..... 47

Introdução

Durante décadas, promovemos a digitalização como alternativa "limpa" aos processos industriais tradicionais, imaginando data centers como catedrais etéreas de processamento de informação. No entanto, a busca por inteligência artificial (IA) sustentável pode estar exacerbando uma das crises ambientais mais urgentes de nosso tempo.

Diante disso, deparamo-nos com um paradoxo fundamental: enquanto a inteligência artificial promete otimizar praticamente todos os aspectos da sociedade industrial – desde redes elétricas até sistemas agrícolas – sua própria infraestrutura representa uma nova fronteira de intensificação material com impactos hídricos cada vez mais documentados.

Um corpo crescente de evidências sugere que nossa obsessão coletiva com modelos fundacionais de IA está precipitando uma crise hídrica irônica e potencialmente catastrófica (Koomey e Masanet., 2021).

A crescente demanda por recursos essenciais (energia, água) imposta pela infraestrutura de IA, notadamente pelos centros de dados, requer grandes quantidades de recursos

hídricos para seu funcionamento, prejudicando dessa forma a sustentabilidade do processo. Por exemplo, modelos de larga escala como o GPT-3 podem demandar milhões de litros de água serve menos como um ponto final e mais como um prólogo para um questionamento bem mais profundo (Luccioni et al., 2023).

Do mesmo modo, relatórios da NPR, relatam que o data center médio consome aproximadamente 300.000 galões de água por dia para manter-se refrigerado, equivalente ao consumo de água em 100.000 lares (Lenovo, 2024). Apenas em 2023, investimentos em data centers ultrapassaram US$200 bilhões, com projeções indicando que esta figura pode duplicar até 2027 (Mordor Intelligence, 2025).

Assim, como podemos, de fato, aquilatar a sustentabilidade de sistemas tecnológicos cujos benefícios se proclamam globais e distribuídos, enquanto seus custos ambientais – como a sede por água e energia – se manifestam de forma intensamente localizada, onerando ecossistemas e comunidades específicas?

Esta revisão sistemática parte da premissa de que uma resposta adequada a tal indagação exige um deslocamento para além da mera colheita de "melhores dados" – um imperativo, sem dúvida – em direção à formulação de *frameworks* conceituais fundamentalmente distintos.

Uma vez, que a literatura especializada, ainda que em expansão, parece identificar, implicitamente, três lacunas críticas que este trabalho se propõe a enfrentar: uma lacuna

metodológica, referente à forma como mensuramos e interpretamos os impactos; uma lacuna temporal, ligada à nossa capacidade de antever e gerir as consequências de longo prazo em ciclos de inovação acelerados; e, talvez a mais crucial, uma lacuna sociotécnica, que subestima a intrínseca interconexão entre as escolhas tecnológicas e suas ramificações sociais, políticas e ecológicas.

Nesse sentido, este trabalho estabelece como objetivo central a análise crítica da literatura científica emergente sobre o consumo de água vinculado à inteligência artificial e suas implicações ambientais.

Especificamente, procuramos, quantificar a demanda hídrica associada a diferentes arquiteturas e aplicações de IA; catalogar e comparar, sob uma ótica de eficiência hídrica, as diversas tecnologias de resfriamento empregadas em *data centers* que suportam cargas de trabalho de IA; e analisar as variações regionais e temporais na pegada hídrica da IA. Além disso, busca-se discutir métodos de mitigação dos impactos hídricos causados.

A contribuição distintiva que se almeja, fundamentalmente, incitar uma reconceituação do problema, a partir de uma abordagem que reconheça e incorpore as dimensões sociais, políticas e ecológicas que se encontram indelevelmente entrelaçadas na materialidade hídrica da IA. Pois, a questão talvez não seja simplesmente "*quanto*" água a IA consome. Antes, impõe-se investigar "*como*" podemos e

devemos reorganizar nossa própria compreensão de sustentabilidade tecnológica, de modo a enfrentar, com rigor intelectual e responsabilidade ética, a contradição entre benefícios potencialmente distribuídos em escala global e custos ambientais intensamente localizados e, por vezes, perversamente invisibilizados.

Referencial teórico

A tarefa de compreender a evolução do debate sobre os impactos ambientais inerentes ao avanço das tecnologias digitais em larga escala revela, curiosamente, uma trajetória de focos seletivos. Por um considerável período, e compreensivelmente dada a urgência climática, a pegada de carbono monopolizou as atenções nos estudos sobre sustentabilidade na esfera digital, ofuscando outras dimensões materiais igualmente críticas.

A pegada hídrica das tecnologias de Inteligência Artificial, em particular, permaneceu por tempo excessivo como uma espécie de espectro nos relatórios e análises – uma presença intuída por alguns, mas raramente quantificada ou centralizada no debate acadêmico. Foi somente com a publicação de estudos pioneiros, como o já citado trabalho que metaforicamente questionava a "sede" da IA (Luccioni et al., 2023), que a cortina começou a ser descerrada.

Tais investigações, ao revelarem que o treinamento de grandes modelos de IA, como o paradigmático GPT-3, poderia implicar o consumo de volumes de água na casa dos milhões de litros – a cifra de 5.4 milhões de litros totais, com 700.000 litros de consumo direto *on-site* para o treinamento do GPT-3, é

frequentemente evocada (Li et al., 2023) – catalisou, ou ao menos deveria ter catalisado, um reexame mais profundo.

De acordo com o relatório ambiental da Google de 2024, o consumo de água em seus data centers aumentou aproximadamente 88% desde 2019 Sustainability Magazine (Bloomberg, 2025). De maneira similar, a Microsoft reportou aumento de 34% no consumo total de água do ano fiscal 2021 para 2022 University of Tulsa (Boyd Corporation, 2024). Estes aumentos coincidem precisamente com o crescimento exponencial de cargas de trabalho de IA.

A métrica Water Usage Effectiveness (WUE), desenvolvida pela The Green Grid em 2011, representa uma tentativa de quantificar a eficiência hídrica de data centers, dividindo o uso anual de água em litros pela energia utilizada por equipamentos de TI em kilowatt-horas (Trade., 2024).

Para traduzir estas ordens de grandeza em uma escala mais palpável, a literatura e a imprensa recorrem, com frequência, a analogias com o universo doméstico. Nesse exercício de contextualização, a demanda hídrica diária de um *data center* de porte médio – estimada em 1,1 milhão de litros (ou 300.000 galões) apenas para arrefecimento – é frequentemente equiparada ao consumo de cem mil residências (Lenovo, 2023).

A mesma lógica se aplica à escala anual, onde uma única instalação de 1 megawatt pode requerer até 26 milhões de litros. Essa cifra é então posta em equivalência, não sem alguma simplificação sociológica, ao consumo de 62 famílias

norte-americanas (Lawfare Media, 2024). Contudo, como observam vários especialistas, o WUE padece de limitações conceituais críticas. Shehabi et al. (2024) apontam que, assim como o PUE, as métricas WUE-site e WUE-source não consideram a eficiência de hardware ou desempenho computacional (Dgtl Infra, 2024).

Esta falha fundamental impede comparações significativas entre data centers com diferentes cargas de trabalho e eficiências. Além disso, WUE trata cada litro de água igualmente, apesar de data centers operarem em contextos hidrológicos radicalmente diferentes.

Um valor WUE de 0.2 L/kWh tem implicações completamente distintas quando ocorre em uma região com abundância hídrica versus uma área que enfrenta escassez crônica (Energy Informatics, 2023). Esta equivalência matemática falsa mascara realidades ecológicas regionais crucialmente diferentes (Ebert et al., 2025).

A velocidade da inovação em IA supera nossa capacidade de avaliar impactos ambientais de longo prazo. A ausência de estudos considerando cenários climáticos futuros (2040-2070) representa mais que oversight metodológico – revela nossa dificuldade coletiva em pensar sustentabilidade além de horizontes comerciais convencionais.

As projeções do Lawrence Berkeley National Laboratory sugerem que até 2028, data centers nos EUA poderão consumir até 12% da eletricidade nacional NPR, com

correspondentes aumentos na demanda hídrica não adequadamente modelados (Equinix., 2024).

Estudos técnicos sistematicamente ignoram dimensões de justiça ambiental e distribuição geográfica de impactos. Apesar de dados centers proliferarem em áreas já hidricamente estressadas – do sudoeste americano ao Uruguai – poucas análises integram considerações de equidade distributiva. Um estudo recente revela que 66% dos novos data centers desde 2022 estão em localizações com altos níveis de estresse hídrico Data Center Dynamics (Food and Water Watch, 2025).

Em Bengaluru, Índia, data centers existentes consomem aproximadamente 8 milhões de litros diários (Berger, 2025) – em uma cidade que recentemente enfrentou sua pior crise hídrica em 500 anos. Preocupações similares surgem em Oregon, Uruguai e Inglaterra, onde o consumo crescente de água por data centers intensifica escassez local.

No Arizona, um complexo de data centers da Microsoft poderá utilizar anualmente 56 milhões de galões de água potável, equivalente ao consumo anual de 670 famílias locais (Garcia, 2024).

Esta constatação inicial impulsionou, ainda que de forma incipiente, novas linhas de investigação sobre os múltiplos vetores que compõem a pegada hídrica da IA. A taxonomia usual, que aqui adotamos com ressalvas analíticas a serem expostas adiante, desdobra-se em três escopos principais.

O escopo 1 abarca o consumo direto de água, essencialmente para o resfriamento e a operação dos servidores alojados nos *data centers*.

Penso aqui nos complexos sistemas de climatização e, crescentemente, nos circuitos de refrigeração líquida que se tornam imperativos diante das densidades energéticas dos processadores modernos.

O escopo 2, por sua vez, refere-se ao consumo hídrico indireto, embutido na geração da energia elétrica que alimenta essas instalações famintas; um volume de água cuja magnitude é dramaticamente dependente do *mix* da matriz energética local – pensemos na disparidade entre hidrelétricas em regiões com reservatórios abundantes versus termelétricas a carvão com sistemas de resfriamento abertos em zonas áridas.

Finalmente, o escopo 3 engloba o uso de água "cinza" ou virtual, incorporado ao longo de toda a cadeia de suprimentos, desde a extração de minerais até a fabricação dos *chips* e servidores.

Esta última é, reconhecidamente, a dimensão mais opaca e metodologicamente desafiadora, com dados historicamente escassos e de acesso restrito, uma verdadeira "caixa-preta" na contabilidade ambiental da indústria tecnológica (Strubell, Ganesh, & McCallum, 2019) sobre desafios da análise de ciclo de vida em eletrônicos.

Estudos correlatos, muitos deles oriundos de campos como a ecologia industrial e a avaliação de ciclo de vida,

também começam a iluminar os desafios inerentes às próprias metodologias de mensuração (Ahmed, 2014). A aparente simplicidade de métricas como o WUE mascara, por exemplo, uma considerável diversidade espaço-temporal.

A eficiência hídrica, tal como reportada, pode variar substancialmente não apenas entre diferentes geografias, em função de climas e tecnologias de resfriamento distintas, mas também sazonalmente, introduzindo um grau de incerteza na avaliação precisa do consumo que não pode ser negligenciado (Gao, 2012).

Esta variabilidade, aliás, remete-me a debates que acompanhei de perto durante meu período na TU Delft sobre a otimização de sistemas hídricos urbanos, onde a granularidade espacial e a dinâmica temporal são absolutamente cruciais para uma gestão eficaz (Karimi et al., 2022).

Outras publicações, tangenciando o que se convencionou chamar de "Produtividade Verde" ou "TI Verde" (APO, 2006; Findiastuti, Anityasari, & Singgih, 2011), sugerem que a integração dos diversos impactos ambientais – seja na forma de pegada de carbono, hídrica ou de materiais – deveria evoluir para um indicador mais holístico de desempenho sustentável.

Tal indicador alinharia, idealmente, a proteção ambiental com a própria viabilidade econômica das organizações, embora, na prática, observe-se frequentemente uma hierarquização onde os custos ambientais externalizados

continuam a ser uma nota de rodapé nas estratégias corporativas (Karimi et al., 2022).

Neste contexto, a literatura aponta, quase que em uníssono, para uma premente necessidade de maior transparência e de um rigor aprimorado na divulgação das métricas associadas ao consumo hídrico por parte da indústria de IA (Li et al., 2023).

Embora os denominados *AI model cards* tenham começado a incorporar, ainda que timidamente, estimativas de emissões de carbono, as informações referentes à utilização de água permanecem notavelmente fragmentadas, quando não inteiramente ausentes (Lardinois, 2021).

Esta lacuna, a meu ver, não é apenas técnica, mas sintomática de uma subvalorização sistêmica dos recursos hídricos frente a outros insumos (Strubell, Ganesh, & McCallum, 2019). Evidencia-se, assim, a urgência na adoção de modelos de relatório ambiental mais abrangentes e auditáveis, que incorporem não apenas os dados operacionais diretos, mas também as projeções de demanda futura e, crucialmente, os impactos indiretos ao longo da cadeia de valor (escopo 3), contribuindo para uma governança mais responsável dos recursos hídricos em um planeta onde a água de qualidade se torna um bem cada vez mais disputado. É precisamente nesta interseção entre a demanda tecnológica e a finitude dos recursos que a presente revisão sistemática busca fincar suas análises mais incisivas.

Metodologia

O levantamento bibliográfico dos estudos foi conduzido por meio de uma busca a de estudos publicados, utilizando as bases de dados, Web of Science, ACM Digital Library, Scopus, IEEE Xplore, Google Scholar, Environmental Science & Technology, quanto o que se poderia denominar "literatura cinzenta" de alta relevância – publicações de institutos de pesquisa independentes, documentos de agências governamentais, ArXiv (preprints), National Renewable Energy Laboratory (NREL), Lawrence Berkeley), relatórios de sustentabilidade de técnicos de empresas de tecnologia e operadoras de data centers (Google, Microsoft, Amazon, Meta, Lenovo), publicações de think tanks ambientais, e ONGs internacionais que, não raro, contêm dados e análises que ainda não percolaram para o circuito formal das publicações revisadas por pares.

A busca foi realizada utilizando operadores booleanos e as seguintes palavras-chave: "artificial intelligence" OR "machine learning" OR "deep learning" AND "data center" OR "cloud computing" AND "water use" OR "water consumption" OR "water footprint" AND "environmental impact" OR "sustainability").

Os critérios de inclusão foram definidos com o intuito de capturar estudos que: (a) abordassem explicitamente o consumo de água, direto ou indireto, associado a tecnologias de IA, seus modelos ou sua infraestrutura (especialmente *data centers*); (b) apresentassem dados quantitativos, estimativas, projeções ou análises metodológicas relevantes para a pegada hídrica, e estratégias de mitigação do impacto negativo sobre os recursos hídricos causados pelo uso de IA; (c) fossem publicados entre janeiro de 2015 – um marco temporal que sugere a ascensão mais acentuada dos modelos de *deep learning* – e maio de 2025; e (d) estivessem redigidos em inglês ou português.

Especificamente, foram considerados estudos empíricos primários (quantitativos ou qualitativos), modelagens, simulações, análises de ciclo de vida (LCAs), revisões sistemáticas, meta-análises e estudos de caso detalhados. Foram excluídos artigos puramente especulativos sem fundamentação empírica ou metodológica, editoriais, e trabalhos cujo foco principal divergisse substancialmente da questão hídrica.

A análise dos dados extraídos envolveu uma síntese narrativa das evidências qualitativas e, quando os dados permitiram, uma meta-agregação descritiva dos resultados quantitativos. O foco recaiu não apenas nos valores absolutos de consumo, mas também nas metodologias empregadas, nas incertezas reportadas e, crucialmente, nas lacunas de conhecimento explicitadas ou inferidas.

A intenção nunca foi, e nem poderia ser, alcançar uma "verdade numérica" definitiva sobre a sede da IA, mas sim mapear a complexidade do problema, identificar os contornos do que já se conhece com algum grau de certeza, e, sobretudo, iluminar as vastas áreas que permanecem obscuras. Este processo, naturalmente, permitiu identificar as lacunas – metodológica, temporal e sociotécnica – que orientam a argumentação central deste artigo (Moher, et al., 2009).

Resultados

Pegada hídrica operacional e a sede visível dos *Data Centers*

O escopo 1, referente ao consumo direto de água nos *data centers*, é talvez a faceta mais tangível, embora não necessariamente a mais volumosa, da sede hídrica da IA. Esta água é primordialmente empregada nos sistemas de resfriamento, vitais para manter a temperatura dos servidores dentro de limites operacionais seguros, e, em menor grau, para umidificação e outras necessidades de manutenção predial.

O processo de resfriamento, como descrito na literatura (Patterson et al., 2021), pode envolver desde a refrigeração a ar tradicional até sistemas mais sofisticados de refrigeração líquida direta ao *chip* (*direct-to-chip liquid cooling*) ou por imersão, tecnologias estas que se tornam cada vez mais prevalentes à medida que a densidade de potência dos servidores dedicados ao treinamento de IA atinge patamares inéditos (Patterson et al. 2021; Li et al., 2023).

Estudos que se debruçaram sobre o tema (Apple, 2024; Shehabi et al., 2024) apontam para um consumo considerável. O dado frequentemente mencionado de que o treinamento do GPT-3 em *data centers* específicos nos EUA teria demandado cerca de 700.000 litros de água evaporada *in loco* (Li et al., 2023;

Solomon, 2024), se confirmado como fonte primária para este dado específico ilustra a magnitude do desafio.

Contudo, como engenheira ambiental com experiência em otimização de sistemas, alerto para o perigo de se tomar tais números isoladamente. A eficiência com que essa água é utilizada, frequentemente encapsulada na métrica WUE (Litros/kWh), é crucial (Li et al., 2023). Um WUE "baixo" (idealmente próximo de zero para sistemas de ciclo fechado ou resfriamento a ar sem evaporação, embora na prática valores como 0.2 L/kWh (Microsoft, 2023), sejam considerados eficientes para sistemas evaporativos) indica, teoricamente, um uso mais eficiente (Solomon, 2024).

No entanto, e aqui reside uma das minhas preocupações metodológicas, a métrica WUE, por si só, pode ser enganosa. Ela não distingue, por exemplo, a origem da água (potável, reciclada, pluvial) nem o impacto da sua retirada no ecossistema local, especialmente em regiões sob estresse hídrico (Shehabi et al., 2024); Banse, Rincé & Defour 2024).

Um *data center* pode ostentar um WUE exemplar e, ainda assim, exercer uma pressão insustentável sobre os recursos hídricos locais se estiver captando água de um aquífero superexplorado. A literatura (Bischoff-Mattson et al., 2020**)** sobre gestão de recursos hídricos em zonas áridas tem consistentemente demonstrado que a localização geográfica e as condições climáticas são determinantes (Masud, 2025).

Data centers situados em regiões quentes e secas tendencialmente apresentarão um consumo evaporativo maior, caso utilizem torres de resfriamento, para alcançar o mesmo nível de arrefecimento, exacerbando a contradição entre a natureza "global" da nuvem computacional e a materialidade intensamente "local" de sua infraestrutura. A análise espaço-temporal, portanto, não é um mero detalhe técnico, mas um imperativo ético e de sustentabilidade.

A otimização do "onde" e "quando" – como o texto original sugere ao mencionar a execução de cargas de trabalho em horários ou locais mais frescos – é uma estratégia válida, mas que precisa ser avaliada à luz de possíveis transferências de ônus (e.g., para a rede elétrica em horários de pico).

Consumo hídrico energético indireto

O escopo 2 direciona nosso olhar para a água consumida na geração da eletricidade que alimenta os *data centers*. Esta é uma dimensão frequentemente subestimada pelo público em geral, mas de impacto potencialmente massivo (Meta, 2024). A vasta maioria das formas de geração de energia elétrica – com exceção notável da Solar Fotovoltaica e da eólica, em suas fases operacionais – consome água, seja diretamente nos processos termoelétricos (para produção de vapor e resfriamento de condensadores) ou, no caso das hidrelétricas, pela evaporação dos reservatórios e pela

alteração dos regimes hídricos (Macknick et al., 2011; Shehabi et al. (2024).

Estimativas presentes na literatura (Li et al., 2023) indicam que a quantidade de água necessária por cada kWh pode variar de frações de litro a dezenas de litros, dependendo da fonte primária e da tecnologia de resfriamento da usina geradora (Shehabi et al., 2024). Por exemplo, usinas termelétricas a carvão ou nucleares com sistemas de resfriamento de passagem única (*once-through cooling*) possuem uma pegada hídrica de retirada significativamente maior do que aquelas com torres de resfriamento de ciclo fechado, embora estas últimas tenham maior consumo evaporativo (Scanlon et al., 2013).

Já as usinas a gás de ciclo combinado tendem a ser mais eficientes. A implicação direta para a IA é que a pegada hídrica de escopo 2 de um *data center* é indissociável do *mix* energético da rede à qual ele está conectado. Um *data center* alimentado predominantemente por energia hidrelétrica em uma região com abundância de água terá uma pegada de escopo 2 distinta daquele que depende de termelétricas a carvão em uma bacia hidrográfica já comprometida (Kseibati, 2025).

Esta interdependência, reforça a necessidade de abordagens sistêmicas. Não basta otimizar o WUE dentro das paredes do *data center* (escopo 1) se a energia que o alimenta carrega uma dívida hídrica impagável. Como o texto original bem aponta, o critério de eficiência hídrica relacionado ao escopo 2 torna-se, assim, essencial para uma visão holística. E

aqui se insere outra contradição que me intriga: a busca por energias "limpas" sob a ótica do carbono nem sempre se traduz em uma menor pressão sobre os recursos hídricos.

Algumas fontes renováveis, como certas configurações de energia solar concentrada (CSP) que utilizam ciclos a vapor, ou a produção de hidrogênio "verde" por eletrólise, podem ter demandas hídricas não negligenciáveis, dependendo da tecnologia e do contexto local. A conciliação entre as pegadas de carbono e hídrica, portanto, não é automática e exige uma análise integrada cuidadosa, um ponto que retomarei adiante.

Consumo hídrico na cadeia de suprimentos

O escopo 3, que abrange a água incorporada na fabricação de componentes (semicondutores, servidores, infraestrutura de rede) e em toda a cadeia de suprimentos, representa, possivelmente, o maior desafio tanto em termos de quantificação quanto de mitigação (Frost & Hua, 2019).

Trata-se de uma "pegada hídrica virtual" vasta e difusa, cujos dados, como mencionei anteriormente, são notoriamente escassos e de difícil rastreamento. A produção de semicondutores, o coração pulsante da IA, é um processo industrial altamente intensivo no uso de água de altíssima pureza (água ultrapura), utilizada em múltiplas etapas de lavagem e fabricação dos *wafers*, além da água para o resfriamento das instalações fabrica (Apple, 2024).

Empresas como a Apple, citada no texto original, já reconheceram em seus relatórios de sustentabilidade que a esmagadora maioria de sua pegada hídrica total reside precisamente na cadeia de suprimentos – o número de 99% é impactante e sugestivo do que pode ocorrer em outros segmentos da indústria de alta tecnologia. Transpor essa realidade para o universo da IA significa admitir que a água consumida para treinar um modelo ou operar um *data center* (Escopos 1 e 2) pode ser apenas a ponta do iceberg (Frost & Hua, 2019).

A fabricação dos GPUs especializados, dos TPUs, dos complexos sistemas de memória e armazenamento, todos carregam consigo uma história hídrica que começa na mineração de matérias-primas e se estende por uma complexa rede global de produção e montagem (Apple, 2024).

Esta dimensão da pegada hídrica, frequentemente negligenciada em análises mais superficiais ou focadas apenas na fase de uso, exige um aprofundamento radical na nossa compreensão da materialidade da IA. A ausência de dados robustos e padronizados sobre o escopo 3 não deve servir de álibi para sua desconsideração, mas sim como um chamado urgente à pesquisa e à pressão por maior transparência corporativa (Frost & Hua, 2019; Apple, 2024).

Em sistemas sustentáveis, a integração efetiva dos impactos de escopo 3 na avaliação da sustentabilidade de qualquer tecnologia é um dos maiores desafios metodológicos e de governança do nosso tempo. Sem isso, corremos o risco de

promover soluções que são eficientes em um nível micro (o *data center*) mas que simplesmente transferem o ônus ambiental para outros elos, muitas vezes mais vulneráveis, da cadeia produtiva global. A busca por *frameworks* conceituais que deem conta dessa. Na Tabela 1, é apresentado uma estimativa do consumo de água pela IA.

Tabela 1. Tabela comparativa do consumo direto (resfriamento dos servidores com uso de água), indireto (volume de água associado à geração de energia) e projeções globais do uso hídrico pela IA

Indicador	**Estimativas**	**Fonte**
Consumo direto – GPT-3 (175B)	~700.000 litros (evaporação in loco)	(Li et al., 2023; Data Center Dynamics, 2024)
Treinamento – GPT-3 (175B)	~5,4 milhões de litros	(Luccioni et al., 2023)
Consumo direto - LLaMA- (70B)	22 milhões L	(Harper, 2024)
Consumo de água (Inferência) – GPT-3	~10-50 respostas/500mL	(Li et al., 2023)
Consumo de água (Inferência) – GPT-4	235mL-1408mL/email 100 palavras	(Harper, 2024)
Consumo indireto – Geração de energia por kWh	Varia conforme mix energético (e.g., 3,1 L/kWh -	(Macknick et al., 2025; NREL, 2025)

	4.35 L/kWh)	
Projeção global de retirada de água pela IA (2027)	4,2 a 6,6 bilhões de m³	(Li et al., 2023)
Projeção global de consumo evaporativo de água pela IA (2027)	0,38 a 0,60 bilhões de m³	(Luccioni et al., 2023)
WUE (Water Usage Effectiveness) típico em data centers eficientes	0,2 - 1,5 L/kWh (varia com tecnologia de resfriamento e clima)	(Luccioni et al., 2023; Equinix, 2024; Microsoft Corporation, 2024; Apple, 2024)

Tabela comparativa das estratégias de mitigação

A tabela a seguir (Tabela 2) sintetiza algumas das principais estratégias de mitigação discutidas na literatura, agrupadas por categorias.

É importante, contudo, lê-la não como um cardápio de soluções prontas e isoladas, mas como um conjunto de ferramentas cuja aplicação e eficácia dependem crucialmente do contexto e da integração em uma visão sistêmica e eticamente orientada.

Tabela 2. Tabela comparativa, das estratégias de mitigação, resultados esperados e desafios encontrados

Estratégia	**Benefícios principais esperados**	**Desafios identificados e considerações críticas**
Transparência e relatórios ambientais	Divulgação de impactos, base para responsabilização, incentivo à inovação	Necessidade de padronização rigorosa, auditabilidade, contextualização local, inclusão do escopo 3. Risco de greenwashing se não houver escrutínio e consequências.
Otimização espaço-temporal de cargas	Potencial redução do consumo hídrico e energético	Risco de transferência de ônus ambientais, perpetuação de injustiças geográficas, necessidade de avaliações socioambientais locais robustas e governança participativa. Foco excessivo na eficiência pode mascarar problemas de escala.

Tecnologias de resfriamento inovadoras (e.g., líquida, imersão)	Maior eficiência energética e hídrica (potencial), menor pue/wue	Alto investimento inicial, ciclo de vida dos fluidos refrigerantes, descarte, necessidade de ACV completa. Podem ser otimizações locais que não resolvem o problema sistêmico da demanda crescente.
Uso de fontes de energia de baixa intensidade hídrica	Redução significativa da pegada hídrica do escopo 2	Disponibilidade e intermitência de renováveis, pegada hídrica da produção das tecnologias renováveis (escopo 3), necessidade de integração com a rede e armazenamento.
Design de modelos de ia mais eficientes (algorítmico)	Menor demanda computacional e, consequentemente, de energia e água	Tendência atual para modelos cada vez maiores, complexidade de mensurar a "eficiência" de um modelo em termos de impacto real. Risco de "efeito rebote" (Jevons Paradox).
Práticas de economia circular (reúso de água,	Minimização da captação de água nova, redução de efluentes,	Barreiras técnicas e econômicas, necessidade de planejamento integrado

recuperação de calor)	eficiência de recursos	e simbiose industrial, regulamentações que incentivem a circularidade.
Desenvolvimento de frameworks de avaliação sistêmica e ética	Compreensão profunda das interconexões, base para decisões justas e sustentáveis de longo prazo	Complexidade inerente, resistência a mudanças paradigmáticas, necessidade de colaboração interdisciplinar e engajamento multissetorial. Este é o desafio central que esta revisão busca endereçar.

Ao analisar esta tabela, percebe-se que muitas estratégias focam em otimizações incrementais dentro do paradigma tecnológico vigente. Embora importantes, elas podem não ser suficientes para lidar com a escala do desafio, especialmente se a demanda por processamento de IA continuar sua trajetória exponencial.

Falta, frequentemente, um questionamento sobre a "suficiência" – ou seja, sobre limites para o crescimento e sobre a real necessidade de certas aplicações de IA em face de seus custos socioambientais.

A transição para uma IA verdadeiramente sustentável exigirá, não apenas engenhosidade técnica, mas também

sabedoria ecológica e coragem política para repensar as próprias finalidades e a governança desta poderosa tecnologia. Ao chegarmos a este ponto da análise, torna-se evidente que, apesar dos avanços incipientes na compreensão e quantificação da pegada hídrica da Inteligência Artificial, o território que se descortina à nossa frente é vasto e ainda significativamente marcado por incertezas, desafios metodológicos e, ouso dizer, por uma certa inércia paradigmática.

As reflexões que se seguem não buscam apenas elencar as limitações do conhecimento atual – um exercício necessário em qualquer empreitada científica séria – mas, sobretudo, delinear perspectivas futuras que transcendam a mera acumulação de dados ou o refinamento de tecnologias.

Anseio por um futuro onde a pesquisa e a prática em IA e sustentabilidade hídrica sejam informadas por *frameworks* conceituais mais robustos, eticamente fundamentados e ecologicamente conscientes. Uma das limitações mais flagrantes e persistentemente citadas na literatura, e que minhas próprias incursões confirmam, reside na escassez crônica e na heterogeneidade dos dados publicamente disponíveis sobre o consumo hídrico da IA.

Conforme já ventilado, esta opacidade é particularmente aguda no que concerne ao Escopo 3 – a água incorporada na complexa e globalizada cadeia de suprimentos de componentes eletrônicos e infraestruturas. Enquanto alguns dados operacionais dos escopos 1 e 2 começam a emergir, geralmente de forma agregada e através de relatórios

voluntários de um punhado de grandes corporações, a ausência de informações detalhadas, padronizadas e auditáveis sobre os processos de fabricação e a origem dos materiais continua a ser um obstáculo formidável.

Esta lacuna não é trivial; ela impede a realização de Avaliações de Ciclo de Vida (ACV) verdadeiramente abrangentes e, por conseguinte, obscurece uma parcela significativa – potencialmente a maior – da pegada hídrica total da IA (Frost & Hua, 2019).

A falta de padronização internacional para a mensuração e o reporte dos impactos ambientais da IA, incluindo sua pegada hídrica, agrava o problema. Métricas como o WUE, como já critiquei, podem variar em sua aplicação e interpretação, dificultando comparações fidedignas e permitindo, por vezes, um indesejado "branqueamento hídrico" (waterwashing).

Urge, portanto, o desenvolvimento e a adoção de protocolos de reporte que sejam não apenas padronizados, mas também transparentes quanto às suas premissas metodológicas e suficientemente granulares para permitir uma análise contextualizada.

Acredito que tal avanço não virá apenas da boa vontade corporativa; necessitará de pressão regulatória e de um consenso construído no seio da comunidade científica e da sociedade civil.

O otimismo tecnológico, inerente a muitos discursos sobre a IA, sugere que os próprios avanços na área poderão fornecer ferramentas para mitigar seus impactos. O texto original menciona, por exemplo, o potencial de sensores inteligentes, sistemas de monitoramento em tempo real, big data e análises preditivas para otimizar o uso de água em data centers e para avaliar com maior precisão o consumo hídrico.

De fato, minha experiência com sistemas de monitoramento ambiental na USP e em colaborações internacionais indica que tais tecnologias podem oferecer ganhos de eficiência e uma granularidade de dados antes impensável.

Se o objetivo for meramente otimizar o consumo para reduzir custos operacionais dentro do paradigma de crescimento ilimitado, então corremos o risco de apenas sofisticar o problema, e não de resolvê-lo em sua raiz. As novas metodologias e tecnologias de monitoramento devem estar a serviço de uma governança hídrica mais justa e transparente, e não apenas da eficiência corporativa.

Ademais, as novas metodologias não podem se restringir ao quantitativo. A complexidade do desafio hídrico da IA clama por uma colaboração genuína e robusta entre a academia, a indústria, os governos e, crucialmente, a sociedade civil organizada e as comunidades locais. A colaboração não pode ser um exercício de relações públicas ou um fórum para a legitimação de práticas insustentáveis.

Ela deve ser um espaço de diálogo crítico, onde as assimetrias de poder são reconhecidas e onde as vozes das comunidades mais afetadas e dos pesquisadores independentes tenham peso equivalente ao dos grandes conglomerados tecnológicos.

A implementação de políticas públicas eficazes é, o pilar central para qualquer avanço significativo. Tais políticas devem ir além de meros incentivos fiscais para "tecnologias verdes".

Elas precisam estabelecer: padrões mínimos obrigatórios de eficiência hídrica e de transparência no reporte para data centers e para a cadeia de suprimentos da IA; mecanismos de licenciamento e fiscalização que considerem o impacto hídrico cumulativo e a vulnerabilidade das bacias hidrográficas; precificação da água que reflita seu valor econômico, social e ecológico, e que internalize as externalidades negativas; investimento em pesquisa e desenvolvimento de tecnologias de IA.

E também de infraestruturas que sejam intrinsecamente menos sedentas e que contribuam para a solução de problemas hídricos, em vez de agravá-los; e, zoneamento ecológico-tecnológico que restrinja a instalação de infraestruturas de alta demanda hídrica em áreas de estresse hídrico.

Conclusão

Ao término desta revisão sistemática, emerge com nitidez a constatação de que a relação entre a Inteligência Artificial e o consumo de água transcende, em muito, uma mera questão de eficiência técnica ou de otimização de recursos.

O que se desvela é um desafio de contornos epistemológicos, éticos e de governança consideravelmente mais profundos, intrinsecamente ligado àquela contradição que me propus a investigar: a de sistemas tecnológicos que prometem benefícios em escala global, enquanto impõem custos ambientais – como a crescente demanda hídrica – de forma intensamente localizada e, não raro, desigualmente distribuída.

A presente análise, ao sintetizar e escrutinar criticamente a literatura emergente, buscou não apenas mapear o estado da arte do conhecimento sobre esta "sede" tecnológica, mas, fundamentalmente, argumentar em favor de uma reconceitualização da própria maneira como compreendemos e avaliamos a sustentabilidade na era digital.

As evidências quantitativas, embora ainda fragmentadas e permeadas por incertezas metodológicas, são inequívocas em apontar para uma demanda hídrica

significativa e potencialmente crescente por parte da infraestrutura de IA, especialmente no que tange ao treinamento de modelos de larga escala e à operação de data centers. As projeções para os próximos anos acendem um alerta que não pode ser ignorado, sob pena de agravar as já prementes crises hídricas em diversas regiões do globo.

Demonstrou-se, outrossim, a imperatividade de uma análise que contemple os três escopos de consumo – o direto-operacional (Escopo 1), o indireto-energético (Escopo 2) e, de forma crucial, o consumo incorporado ao longo da vasta e opaca cadeia de suprimentos (Escopo 3).

Este último, em particular, representa um "continente submerso" na contabilidade ambiental da IA, cuja exploração exige um compromisso renovado com a transparência corporativa e o avanço de metodologias de avaliação de ciclo de vida mais robustas e abrangentes.

Ademais, esta revisão reforçou a crítica à falácia das médias globais e à insuficiência de métricas isoladas como o Water Usage Effectiveness quando descontextualizadas. A variabilidade espaço-temporal dos impactos hídricos é um fato incontornável.

Um litro de água consumido em uma bacia hidrográfica sob estresse severo não possui o mesmo significado ecológico, social ou político que um litro consumido em um contexto de abundância – uma nuance que exige a incorporação explícita de princípios de justiça hídrica e de análise de vulnerabilidade localizada nas avaliações de

sustentabilidade. A literatura corrente, com seu foco predominante em otimizações técnicas, ainda tangencia, a profundidade desta dimensão sociotécnica.

Nesse sentido, a principal contribuição que este trabalho almeja transcende a mera compilação de dados ou a catalogação de estratégias de mitigação. Reside, antes, no veemente chamado à superação do paradigma tecnocrático dominante e à urgência no desenvolvimento e adoção de novos *frameworks* conceituais.

Tais *frameworks* devem ser capazes de integrar, de forma sistêmica e crítica, as dimensões de escala (global versus local), temporalidade (impactos de curto, médio e longo prazo, em ciclos de inovação acelerados) e, fundamentalmente, de justiça socioambiental. Sem essa reconceitualização, corremos o risco de continuar a propor "soluções" que, na melhor das hipóteses, são paliativas e, na pior, podem exacerbar desigualdades preexistentes ou criar novas formas de externalização de custos ambientais.

Referências

Amazon Web Services. (2023). AWS Water Stewardship Report 2023. Recuperado de https://sustainability.aboutamazon.com/water-stewardship-report-2023.pdf

Andreichik, O. (2025). *Impact of AI on Sustainability*. Theseus Applied Sciences. Disponível em: https://www.theseus.fi/handle/10024/881347
Apple Inc. (2023). Environmental Progress Report: Water Stewardship. Recuperado de https://www.apple.com/environment/pdf/Apple_Environmental_Progress_Report_2023.pdf

Aquatech Trade. (2024). Environmental report Google water stewardship plans. *Aquatech*. Disponível em: https://www.aquatechtrade.com/news/water-reuse/google-water-stewardship-environmental-report-ai

Berger, A. (2025). *Artificial Intelligence Data Centers and United States Based Hyperscalers: Impacts and Solutions*. Johns Hopkins University. Disponível em: https://jscholarship.library.jhu.edu/items/8792d5a5-91a3-4179-bc73-61fcc2ae1879

Bloomberg. (2025). How AI Demand Is Draining Local Water Supplies. *Bloomberg Graphics*. Disponível em:

https://www.bloomberg.com/graphics/2025-ai-impacts-data-centers-water-data/

Boyd Corporation. (2024). Energy Consumption in Data Centers: Air versus Liquid Cooling. *Boyd Corporation Blog*. Disponível em: https://www.boydcorp.com/blog/energy-consumption-in-data-centers-air-versus-liquid-cooling.html

Data Center Frontier. (2024). Comparing and Contrasting Liquid Cooling Technologies. *Park Place Technologies*. Disponível em: https://www.datacenterfrontier.com/sponsored/article/55132034/park-place-technologies-comparing-and-contrasting-immersion-cooling-technologies

Dgtl Infra. (2024). Data Center Water Usage: A Comprehensive Guide. Disponível em: https://dgtlinfra.com/data-center-water-usage/

Dodge, J., Prewitt, T., Tachet des Combes, R., Odmark, E., Schwartz, R., Strubell, E., ... & Luccioni, A. S. (2022). Measuring the carbon intensity of AI in cloud instances. In Proceedings of the 2022 ACM Conference on Fairness, Accountability, and Transparency (pp. 1877-1894). https://doi.org/10.1145/3531146.3533234

Ebert, K., Alder, N., Herbrich, R., & Hacker, P. (2024). AI, Climate, and Regulation: From Data Centers to the AI Act. *arXiv preprint arXiv:2410.06681*. Disponível em: https://arxiv.org/abs/2410.06681

Energy Informatics. (2023). Enough hot air: the role of immersion cooling. *SpringerOpen*. Disponível em: https://energyinformatics.springeropen.com/articles/10.1186/s42162-023-00269-0

Equinix. (2024). What Is Water Usage Effectiveness (WUE) in Data Centers? *Equinix Blog*. Disponível em: https://blog.equinix.com/blog/2024/11/13/what-is-water-usage-effectiveness-wue-in-data-centers/

Food and Water Watch. (2025). How AI's Energy and Water Footprints Threaten Climate Progress. Disponível em:https://www.foodandwaterwatch.org/wp-content/uploads/2025/03/FSW_0325_AI_Water_Energy.pdf

Garcia, M. (2024). AI Uses How Much Water? Navigating Regulation Of AI Data Centers' Water Footprint Post-Watershed Loper Bright Decision. *SSRN*. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5064473

Google LLC. (2023). Environmental Report: A sustainable future with AI. Recuperado de https://sustainability.google/reports/environmental-report-2023/

Google. (2024). Our commitment to climate-conscious data center cooling. *Google Blog*. Disponível em: https://blog.google/outreach-initiatives/sustainability/our-commitment-to-climate-conscious-data-center-cooling/

Harper, C. (2024). Using GPT-4 to generate 100 words consumes up to 3 bottles of water. *Tom's Hardware*. Disponível em: https://www.tomshardware.com/tech-industry/artificial-intelligence/using-gpt-4-to-generate-100-words-consumes-up-to-3-bottles-of-water-ai-data-centers-also-raise-power-and-water-bills-for-nearby-residents

Henderson, P., Hu, J., Romoff, J., Brunskill, E., Jurafsky, D., & Pineau, J. (2020). Towards the systematic reporting of the energy and carbon footprints of machine learning. Journal of Machine Learning Research, 21(248), 1-43. https://jmlr.org/papers/v21/20-312.html

Hoosain, M. S., Paul, B. S., Kass, S., et al. (2023). Tools towards the sustainability and circularity of data centers. *Circular Economy and Sustainability*, 3, 1-25. Springer. https://doi.org/10.1007/s43615-022-00191-9

Impax Asset Management. (2024). Addressing the hidden water footprint of data. *Impax AM Blog*. Disponível em: https://impaxam.com/insights-and-news/blog/addressing-the-hidden-water-footprint-of-data/

Jha, R., Jha, R., & Islam, M. (2025). Forecasting US data center CO2 emissions using AI models: emissions reduction strategies and policy recommendations. *Frontiers in Sustainability*. Disponível em: https://www.frontiersin.org/journals/sustainability/articles/10.3389/frsus.2024.1507030/full

Kez, D. A., Foley, A., Wong, F. W., et al. (2025). AI-Driven Cooling Technologies for High-Performance Data Centers:

State-of-The-Art Review and Future Directions. *SSRN*. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5148380

Kseibati, R. (2025). *Cooling Innovation and Circularity: Addressing Water Stress in the Age of AI-Driven Data Centers*. MIT. Disponível em: https://dspace.mit.edu/handle/1721.1/158889

Lannelongue, L., Grealey, J., Inouye, M. (2021). Green algorithms: Quantifying the carbon footprint of computation. Advanced Science, 8(12), 22100707. https://doi.org/10.1002/advs.202100707

Lawfare Media. (2024). AI Data Centers Threaten Global Water Security. Disponível em: https://www.lawfaremedia.org/article/ai-data-centers-threaten-global-water-security

Lenovo. (2024). The world's AI generators: rethinking water usage in data centers. *Lenovo News*. Disponível em: https://news.lenovo.com/data-centers-worlds-ai-generators-water-usage/

Li, P., Yang, J., Islam, M. A., & Ren, S. (2023). Making AI Less "Thirsty": Uncovering and Addressing the Secret Water Footprint of AI Models. "arXiv preprint arXiv:2304.03271". Disponível em: https://arxiv.org/pdf/2304.03271

Luccioni, A. S., Viguier, S., & Ligozat, A. L. (2023). Making AI less 'thirsty': Uncovering and addressing the secret water footprint of AI models. arXiv:2304.03271 [cs.CY]. https://arxiv.org/abs/2304.03271

Masud, M. M., Shamem, A. S. M., Saif, A. N. M., et al. (2025). The role of artificial intelligence in sustainable water management in Asia: a systematic literature review with bibliographic network visualization. *Journal of Energy and Water Engineering*. Springer.https://doi.org/10.1007/s42108-024-00319-7

Microsoft Corporation. (2023). Microsoft Water Stewardship Report 2023: Advancing water positive strategies. Recuperado de https://www.microsoft.com/en-us/corporate-responsibility/sustainability/water-positive

Microsoft Corporation. (2024). *Microsoft 2024 Environmental Sustainability Report*. Disponível em: https://cdn-dynmedia-1.microsoft.com/is/content/microsoftcorp/microsoft/msc/documents/presentations/CSR/Microsoft-2024-Environmental-Sustainability-Report.pdf

Mitchell, M., Wu, S., Zaldivar, A., Barnes, P., Vasserman, L., Hutchinson, B., ... & Gebru, T. (2019). Model cards for model reporting. In Proceedings of the Conference on Fairness, Accountability, and Transparency (pp. 220-229). https://doi.org/10.1145/3287560.3287596

Mytton, D. (2021). Data centre water consumption. npj Clean Water, 4(1), 1-6. https://doi.org/10.1038/s41545-021-00101-w

Patterson, D., Gonzalez, J., Le, Q., Liang, C., Munguia, L. M., Rothchild, D., So, D., Texier, M., & Dean, J. (2021). Carbon emissions and large neural network training. arXiv:2104.10350 [cs.LG]. https://arxiv.org/abs/2104.10350

Schwartz, R., Dodge, J., Smith, N. A., & Etzioni, O. (2020). Green AI. Communications of the ACM, 63(12), 54-63. https://doi.org/10.1145/3381831

Wu, L., Fulton, W., Weng, Y., Yuan, W., & Xu, M. (2022). Water and carbon footprints of electricity are sensitive to geographical attribution methods. Environmental Science & Technology, 56(19), 13908-13918. https://doi.org/10.1021/acs.est.2c04233

Yun, Y., Lee, M., & Yan, J. (2022). Green productivity in organizations: The role of carbon and water footprints. Journal of Cleaner Production, 330, 129912. https://doi.org/10.1016/j.jclepro.2021.129912

Zhang, C., Sun, Y., Mo, Y., Zhang, Y., Bu, S. (2020). Water footprint assessment of energy consumption in China based on an input-output framework. Journal of Cleaner Production, 271, 122461. https://doi.org/10.1016/j.jclepro.2020.122461

Zhang, C., Sun, Y., Mo, Y., Zhang, Y., Bu, S. (2020). Water footprint assessment of energy consumption in China based on an input-output framework. Journal of Cleaner Production, 271, 122461. https://doi.org/10.1016/j.jclepro.2020.122461

GEASE